

Федеральное государственное автономное
образовательное учреждение
высшего образования
«СИБИРСКИЙ ФЕДЕРАЛЬНЫЙ УНИВЕРСИТЕТ»
Институт космических и информационных технологий
Кафедра информатики

УТВЕРЖДАЮ

Заведующий кафедрой

_____ А.С Кузнецов

подпись инициалы, фамилия

« _____ » _____ 20 ____ г.

БАКАЛАВРСКАЯ РАБОТА

27.03.03 — Системный анализ и управление

Формирование персонализированного предложения на основе личных
предпочтений клиента

Руководитель

подпись, дата

должность, ученая степень

А.А. Даничев

инициалы, фамилия

Выпускник

подпись, дата

Б.В. Вавулин

инициалы, фамилия

Красноярск 2017

СОДЕРЖАНИЕ

РЕФЕРАТ	3
ВВЕДЕНИЕ	4
1 Рекомендательные системы	5
1.1 Примеры рекомендательных систем.....	5
1.1.1 Рекомендательные системы на основе признаков описаний.....	5
1.1.2 Рекомендательные системы коллаборативной фильтрации	6
1.1.2.2 Анамнестические алгоритмы коллаборативной фильтрации.....	8
1.1.2.2.1 Метрики.....	10
1.1.2.3 Модельные алгоритмы коллаборативной фильтрации	10
1.1.2.3.1 Сингулярное разложение	11
1.4 Значение качества рекомендаций	12
2 Разработка программного обеспечения.....	13
2.1 Исходные данные.....	13
2.2 Аналоги программного продукта.....	14
2.3 Решение проблемы холодного старта	14
2.4 Работы пользователя с системой.....	15
3 Апробация программы и результаты исследования.....	17
3.1 Апробация программного продукта	17
ЗАКЛЮЧЕНИЕ.....	19
СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ	20
ПРИЛОЖЕНИЕ А Кластеризация данных.	22
ПРИЛОЖЕНИЕ Б Графический интерфейс приложения.....	23

РЕФЕРАТ

Выпускная квалификационная работа по теме «Формирование персонализированного предложения на основе личных предпочтений клиента» содержит 24 страницы текстового документа, 13 используемых источников, 7 иллюстраций, 2 таблицы.

Ключевые слова: коллаборативная фильтрация, рекомендательная система, сингулярное разложение, user-based, item-based.

Объект исследования: профиль пользователя.

Цель исследования: разработка рекомендательной системы, позволяющей получать персонализированные рекомендации фильмов.

В результате данной работы проведено изучение рекомендательных систем, изучена литература по данной теме, рассмотрены алгоритмы коллаборативной фильтрации.

В итоге было получено сравнение методов коллаборативной фильтрации в рекомендательных системах.

ВВЕДЕНИЕ

В настоящее время в интернете пользователь обрабатывает большое количество информации, и важную роль играют системы, которые помогают пользователям ориентироваться в данной информации. Пользователи не способны проанализировать всю информацию, которые может его заинтересовать. Для этого активно используются автоматизированные системы, которые способны анализировать большое количество информации в короткие промежутки времени. Такие системы предоставляют пользователю персонализированную рекомендацию. Для получения качественной рекомендации, система должна иметь достаточное количество информации о пользователе.

Объектом исследования работы является профили пользователей, которые пользователь заполняет при регистрации в приложении. Профиль содержит в себе:

1. Фамилия, имя;
2. Пол;
3. Возраст;
4. Рейтинг к фильмам (не менее 20).

В результате система имеет базовую информацию для составления рекомендацию пользователю.

Предметом исследования является методология создания рекомендаций. Различные подходы для создания рекомендаций, алгоритмы и методы, необходимо учитывать для получения наиболее точного результат исследования.

Целью данной работы является разработка рекомендательной системы фильмов.

Задачи

1. Провести анализ существующих алгоритмов для составления рекомендаций;
2. Разработать рекомендательную систему для фильмов.

1 Рекомендательные системы

Рекомендательные системы [1] — системы анализирующие интересы пользователей и пытающиеся сделать прогноз о том, что именно будет интересно для активного пользователя.

Рекомендательные системы помогают пользователям разбираться в большом количестве информации, на сайтах. В некоторых случаях, когда ресурс содержит большое количество информации, данная функция является необходимостью. К примеру, сайте IMDb на данном сайте размещено около четырех миллионов фильмов и телесериалов. Пользователь не сможет просмотреть все что есть на сайте, поэтому поиск новых фильмов пользователи производят, на основе рекомендаций.

1.1 Примеры рекомендательных систем

1.1.1 Рекомендательные системы на основе признаков описаний

В РС на основе признаков описания заключение о полезности $p(u, i)$ объекта i для пользователя u производится, из нужности $\square\square$,

объекта

$\square\square \in \square$

для пользователя. Так в РС, для рекомендации фильма пользователю, система пытается найти сходство между фильмами, которые хорошо оценил пользователь ранее, и фильмы, которые обладают большой степенью схожести с интересами пользователя будут, рекомендованы. Данный вид РС работает на методах анализа и поиска информации, из-за этого такие РС работают с объектами, которые содержат текстовую информацию. Также информация берется из профиля пользователя, информация для профиля заполняется, через опросы и анкеты или косвенно — через анализ действий пользователя.

Кроме эвристических методов, есть и другие методы:

1. Байесов классификатор;
2. Деревья решений;
3. Искусственные нейронные сети.

Данные методы отличаются, так как они делают предсказания основываясь на прошлые данные, полученные при анализе и машинном обучении.

Одной из проблем РС такого типа являются узкие рекомендации, так как системы рекомендуют те объекты характеристики, которых схожи с характеристиками в профиле потребителя. Например, пользователь, который оценивал большое количество комедийных фильмов, никогда не получит рекомендацию на даже на самый известный детективный фильм. Для решения данной проблемы, часто используют фактор случайности. Другой проблемой является то, что два разных объекта, с одинаковым списком свойств, невозможно отличить.

1.1.2 Рекомендательные системы коллаборативной фильтрации

Коллаборативная фильтрация (КФ) [3] — метод рекомендаций, дающий рекомендации, анализирующий прошлые действия пользователей с объектами. Целью данного метода является предсказание оценки, которую поставит активный пользователь, не оцененным им объектам.

Большинство РС, использующих КФ, требуют от пользователя активного взаимодействия с системой, для получения рекомендаций. Например, прежде чем выдать список рекомендуемых фильмов, системе нужно получить оценки определенного количества ранее просмотренных фильмов.

У методов КФ также есть проблемы. Проблема холодного старта является одной из них. Система не может создать рекомендации для нового

пользователя, который еще не оценивал объекты. Также система не может рекомендовать новый объект, который не получил определенное количество оценок от пользователей. Кроме того, в РС, количество оценок, которые система должна предсказать, превышает количество известных оценок.

Обычные РС коллаборативной фильтрации, работают в двумерном пространстве «пользователь-товар». РС делают рекомендации, основываясь только на информации о пользователях или товарах и не используют контекстную информацию, которая может помочь при создании рекомендаций.




Рисунок 1.1 — Сходства и различия, используемые в коллаборативной фильтрации

Постановка задачи коллаборативной фильтрации. Имеется список k пользователей

$\{1, 2, \dots, k\}$

и список предметов n

$\{1, 2, \dots, n\}$

. Каждый пользователь

$\{1, 2, \dots, n\}$

имеет список предметов оцененных пользователем

$\{1, 2, \dots, n\}$

. Активный пользователь

$\{1, 2, \dots, n\}$

, для данного пользователя будет происходить поиск рекомендаций.

Рекомендацией называется список из M объектов,

$\{i\} \in \{j\}$

, которые подходят под интересы активного пользователя. Список $\{i\}$

должен состоять из фильмов, которые активный пользователь ранее не оценивал

$\{i\} \cap \{j\} = \emptyset$

.

На входе алгоритм принимает матрицу размеров $n \times m$, пример показан на таблице 1.1. Элементами матрицы являются r_{ij} , i

оценки i — ого пользователя для j — ого объекта.

Таблица 1.1 — Пример матрицы оценок

—	Объект 1	Объект 2	Объект 3	...	Объект n
Субъект 1	4	?	3	...	
Субъект 2	?	3	5	...	
Субъект 3	3	4	?	...	
...
Субъект k				...	

Алгоритмы для коллаборативной фильтрации можно разделить на две основные группы [7]:

1. Анамнестические (memory-based);
2. Модельные (model-based).

1.1.2.2 Анамнестические алгоритмы коллаборативной фильтрации

Анамнестические алгоритмы [7],[8],[9] прогнозируют оценки объекта пользователем, исходя из всех предшествующих оценок, сделанных данным пользователем, т. е. не

оцененный ранее пользователем объект получает такую оценку, какую дали ему те пользователи, схожи похоже оценили ранее оцененные пользователем объекты. В основном в рекомендательных системах схожесть между двумя пользователями опирается на то, какие оценки они дали одинаковым товарам.

Значение неизвестного рейтинга для пользователя и объекта

рассчитывается как сумма оценок, полученных товаром от других пользователей.

$$r_{u,i} = \frac{1}{|N(u,i)|} \sum_{i' \in N(u,i)} r_{u,i'} \quad (1.1)$$

$$r_{u,i} = \frac{1}{|N(u,i)|} \sum_{i' \in N(u,i)} \text{sim}(u, u') \times r_{u',i} \quad (1.2)$$

$$r_{u,i} = \bar{r}_u + \frac{1}{|N(u,i)|} \sum_{i' \in N(u,i)} \text{sim}(u, u') \times (r_{u',i} - \bar{r}_{u'}), \quad (1.3)$$

где

$$1/|N(u,i)| \sum_{i' \in N(u,i)} |\text{sim}(u, u')|$$

– нормирующий множитель;

$$\bar{r}_u$$

– средняя оценка пользователя.

В рекомендательных системах, использующих коллаборативную фильтрацию используются различные подходы для вычисления сходства между пользователями. В основном сходство между пользователями полагается на то, какие оценки оба пользователя дали одинаковым товарам. Наибольшую популярность получили корреляционный метод и метод линейного сходства. В корреляционном методе, для вычисления сходства используют коэффициент корреляции Пирсона (1.5).

При подходе, который использует метод линейного сходства, пользователи

и

представляются в виде векторов, теперь сходство между пользователями может быть рассчитано как косинус угла между ними (1.6).

При фильтрация по схожести пользователей, идет поиск зависимостей между активным пользователем

и

и другими пользователями. Для данного пользователя рассчитывается мера сходства с другими пользователями. Далее находятся k – пользователей для которых максимальна мера сходства с активным пользователем. Зная предпочтения пользователя и его соседей, система генерирует список из n фильмов, которые должны понравится активному пользователю.

Алгоритм фильтрации по схожести предметов [6] схож с алгоритмом фильтрации по схожести пользователей. Основная идея заключается в расчете схожести объекта, оцененного пользователем с другими объектами. Плюсом данного алгоритма является, то что матрицу схожести объектов можно рассчитать в оффлайн режиме, что позволяет пользователю быстрее получить рекомендацию. Данный алгоритм нужно использовать, когда количество пользователей превосходит количество объектов, находящихся на ресурсе.

1.1.2.2.1 Метрики

Для нахождения сходства пользователей или объектов можно использовать следующие метрики:

1. Евклидова метрика;

$$d = \sqrt{\sum_{i=1}^n (u_i - v_i)^2} \quad (1.4)$$

2. корреляция Пирсона;

$$r = \frac{\sum_{i=1}^n (u_i - \bar{u})(v_i - \bar{v})}{\sqrt{\sum_{i=1}^n (u_i - \bar{u})^2 \sum_{i=1}^n (v_i - \bar{v})^2}} \quad (1.5)$$

3. коэффициента сходства Жаккара;

$$|A \cap B| = |A| \cdot |B| \cdot \cos(\theta) \quad (1.6)$$

4. косинусная мера сходства.

$$\cos(\theta) = \frac{|A \cap B|}{\sqrt{|A| \cdot |B|}} = \frac{|A \cap B|}{\sqrt{|A| \cdot |B|}} \quad (1.7)$$

1.1.2.3 Модельные алгоритмы коллаборативной фильтрации

Модельные алгоритмы [10,11,12,13] в отличие от анамнестических методов, прогнозируют оценки основываясь на некоторой модели поведения.

Например, в [11] предлагается вероятностный подход, где неизвестные оценки просчитываются по формуле (1.8).

$$r_{u,i} = \mu + b_u + b_i + \sum_{k=1}^K \lambda_k \cdot \mu_{u,i,k} \quad (1.8)$$

Делается допущение, что значение оценок — это целые числа от 0 до 5 и вероятностное выражение означает, что пользователь u даст оценку товару i исходя из его прошлых оценок. Для оценки вероятности, в [11] предлагается две вероятностные модели: кластерные модели и Байесовы сети. В первой модели похожие пользователи объединяются в кластеры. Исходя из принадлежности пользователя к кластеру, оценки пользователя считаются независимыми.

Вторая модель представляет каждый объект как один из узлов Байесовой сети, где положение узла соответствует прогнозируемой величине оценки объекта.

созданной с помощью анализа данных, используя, кластеры, Байесовские сети. Для эффективного прогнозирования рекомендательной системы при небольшом количестве данных. Для решения проблем разреженности при поиске схожих пользователей можно использовать сведения их профилей и находить пользователей со схожими профилями.

1.1.2.3.1 Сингулярное разложение

Сингулярное разложение (Singular Values Decomposition, SVD) является удобным методом для работы с матрицами. Сингулярное разложение используют при решении различных задач — приближение методом наименьших квадратов, решение систем уравнений и т.д. Используют различные свойства данного разложения, например, способность показывать ранг матрицы и приближение матрицы данного ранга.

В теореме о сингулярном разложении (SVD) [2] утверждается, что у матрицы A размера $m \times n$

существует разложение в произведение трех матриц формула (1.9).

$$A = U \Sigma V^T \quad (1.9)$$

, где U — матрица

и

$$U^T U = I$$

ортогональные, V — матрица $n \times n$ а

Σ — диагональная.

Усеченное разложение матрицы состоит в следующем. Пусть исходная матрица A размера $m \times n$

представлена в виде $A = U \Sigma V^T$.

Тогда при нахождении обратной матрицы A^{-1}

$$A^{-1} = V \Sigma^{-1} U^T$$

из-за ортогональности матрицы U и V :

$$\lambda_1^2 + \lambda_2^2 + \dots + \lambda_n^2 = 0,$$

и в условия убывания диагональных элементов матрицы $(\lambda_1, \dots, \lambda_n)$.

Будем считать первые r сингулярных чисел матрицы D определяющими пространство матрицы D . Тогда разложение матрицы будет иметь вид рисунок 1.2.




Рисунок 1.2 — Усеченное сингулярное разложение

1.4 Значение качества рекомендаций

Одной из стандартных метрик для предсказания оценки в рекомендательных системах является метрика RMSE, данная метрика вычисляется по формуле (1.10).

$$RMSE = \sqrt{\frac{1}{|I|} \sum_{(u,i) \in I} (\hat{r}_{ui} - r_{ui})^2}, \quad (1.10)$$

где

$$\hat{r}_{ui}$$

- предсказанная оценка;

— пользователь;

— объект;

— оценка

— общее количество тестовых оценок.

2 Разработка программного обеспечения

2.1 Исходные данные

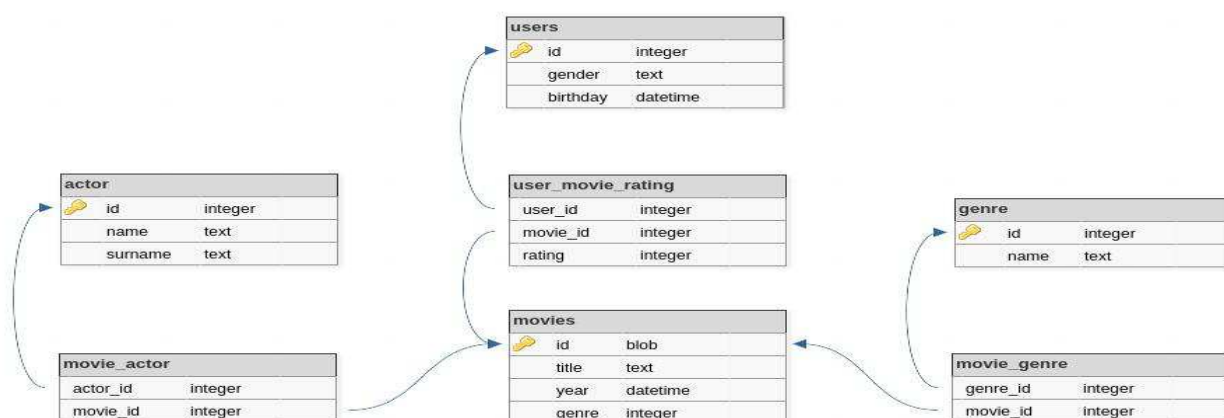
Объектов исследования являются профили пользователей.

Требуется разработать программное обеспечение, позволяющее получать рекомендации пользователю, получая в качестве исходных данных информацию, которая содержится в профиле пользователя.

Сбор информации производился при помощи пользовательского интерфейса приложения. Данные о пользователе заносятся в базу данных. Для тестирования приложения использовались данные пользователей и фильмов взятые с сайта <https://grouplens.org/datasets/movielens/100k/> содержащие:

1. 943 пользователя;
2. 1682 фильма;
3. 90000 оценок пользователей к фильмам.

После данные были обработаны с помощью, модуля, написанного на языке Ruby и занесены в базу данных. Архитектура базы данных изображена на



рисунке 2.1

Рисунок 2.1 — Архитектура базы данных

2.2 Аналоги программного продукта

Разработанный программный продукт не является уникальной разработкой на данный момент времени. Существует множество аналогов. Но каждый программный продукт создается для решения определенного количества задач. Почти невозможно найти универсальный программный продукт, который решал бы все необходимые задачи. Ближайшим аналогом данного продукта является сайт «Кинопоиск» данный сайт предоставляет пользователю список рекомендуемых фильмов, но для получения рекомендаций необходимо оценить около 40 фильмов. Разработанный программный продукт позволяет пользователю получить рекомендацию сразу после регистрации. Также программный продукт показывают пользователю предсказанную оценки к рекомендуемым фильмам.

2.3 Решение проблемы холодного старта

Для решения проблемы "холодного старта" для пользователей было принято решение, строить демографические категории. Для построения данных категорий использовалась кластеризация. Объектами данной кластеризации являлись пользователи x . Признаками объектов являются - пол и возраст. Для кластеризации использовался метод k -средних. На рисунке А.1 изображена кластеризация по демографическому параметру. После кластеризации при регистрации нового пользователя мы уже знаем к какому кластеру его отнести, и для создания рекомендаций для данного пользователя, система подбирает пользователю список фильмов, которые хорошо оценены большинством пользователей в его демографической категории.

Для решения проблемы холодного старта для объектов было решено выводить новинки в отдельной вкладке, где пользователь может их увидеть рисунок 2.2.

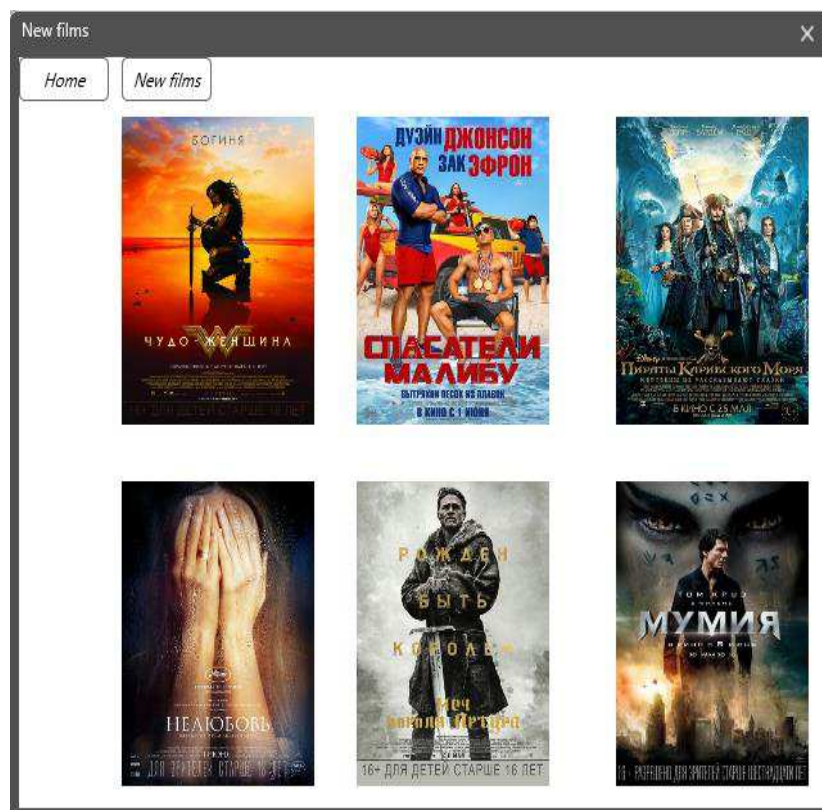


Рисунок 2.2 — Список новых фильмов.

2.4 Работы пользователя с системой

Общение пользователя с системой происходит с помощью пользовательского интерфейса. Для получения пользователем рекомендаций от системы, пользователь должен произвести несколько действий:

1. Произвести регистрацию/вход в приложение рисунок 2.3;
2. Заполнить информацию о себе в профиле рисунок 2.4;
3. Оценить фильмы (рисунок Б.1). После того как пользователь сделает ранее описанные действия, пользователь сможет получить персонализированную рекомендацию рисунок Б.2.

The screenshot shows a window titled 'Home' with a close button (X) in the top right corner. Inside the window, there are two text input fields: the first is labeled 'Input Login' and the second is labeled 'Input Password'. Below these fields are two buttons: 'Register' on the left and 'Log in' on the right.

Рисунок 2.3 — Окно регистрации/входа в приложение

После получения рекомендаций пользователь может продолжить оценивание просмотренных фильмов, и получить новый список рекомендуемых фильмов.

The screenshot shows a window titled 'Account' with a close button (X) in the top right corner. Inside the window, there are three text input fields: the first is labeled 'Name' with the value 'Bogdan', the second is labeled 'Gender' with the value 'Male', and the third is labeled 'Birthday' with the value '22.02.1996'. The 'Birthday' field is highlighted with a blue border. Below these fields is an 'OK' button.

Рисунок 2.4 — Окно заполнения данных профиля

3 Апробация программы и результаты исследования

3.1 Апробация программного продукта

Для проверки работы программы были использованы данные из базы данных, было произведено сравнение оценки и истинного значения.

Ниже представлена таблица, с истинными значениями рейтинга фильма и оценки, рассчитанные различными методами.

Для расчета ошибки была использована формула (1.10), значения ошибки для каждого метода представлены в таблице 3.1.

Таблица 3.1 — Сравнение результатов

Номер	Истинное значение рейтинга	Значение рассчитанное с помощью схожести пользователей	Значение рассчитанное с помощью схожести объектов	Значение рассчитанное с помощью SVD
1	4	3.3251	2.9359	3.2350
2	4	3.1836	3.5574	3.2932
3	4	3.9961	3.4377	4.0204
4	3	3.5522	3.6829	3.4786
5	2	2.7479	3.1400	2.6956
6	4	3.5315	3.2804	3.5256
7	5	4.3563	3.5015	4.4260
8	3	4.3246	3.5192	4.4586
9	5	3.9608	3.7394	3.8630
10	4	3.9984	3.7935	3.9564
11	4	3.5429	3.4345	3.6201
12	5	4.5460	3.1816	4.4797
13	5	4.6296	3.7180	4.7589
14	3	3.0649	3.0012	2.8847
15	3	3.1930	2.8413	3.2016
16	3	3.1237	3.2960	3.1343

Окончание таблицы 3.1

17	4	3.6726	3.5983	3.7605
18	4	3.9899	3.6715	4.0212
19	3	3.1094	3.4107	3.0970
20	1	2.5040	3.3802	2.5634
Значение ошибки RMSE		1.01	1.07	0.96

На рисунке 3.1 представлено графическое отображение сравнения объекта и значения оценок различных методов.




Рисунок 3.1 — Сравнение объекта и оценок

ЗАКЛЮЧЕНИЕ

В работе описана реализации рекомендательной системы для фильмов, представляющая из себя пользовательское приложения для создания рекомендаций.

На основании предпочтений пользователя и его предшествующих оценках фильмов, система может предоставить активному пользователю, персонализированное предложение, которые наиболее похоже к его интересам.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Middleton S. Ontology-Based Recommender Systems : Handbook on Ontologies / Middleton S., De Roure D., Shadbolt N. ; Edt. by S.Staab, R.Studer, Springer, 2009. – 796 с.
2. Machine Learning for AI [Электронный ресурс]: В. В. Стрижов. «Информационное моделирование» — Режим доступа: http://strijov.com/files/eksamen/1_svd.pdf
3. O'Mahony M., Hurley N., Kushmerick N., Silvestre G. Collaborative recommendation: A robustness analysis / O'Mahony M., Hurley N., Kushmerick N., Silvestre G. // ACM Transactions on Internet Technology. 2004.Vol. 4, Issue 4. November. C. 344–377.
4. Sarwar B. et al. Incremental singular value decomposition algorithms for highly scalable recommender systems // Fifth International Conference on Computer and Information Science. – Citeseer, 2002. – С. 27-28.
5. Berry M.W. Large scale singular value computations // International Journal of Supercomputer Applications. – 1992. – № 6(1). – С. 13–49.
6. Пятикоп Е.Е. Исследование метода коллаборативной фильтрации на основе сходства элементов // Наукові праці Донецького національного технічного університету серія: "Інформатика, кібернетика та обчислювальна техніка". – 2013. – №2. – С. 109-114
7. J.S. Breese, D. Heckerman, and C. Kadie, “Empirical Analysis of Predictive Algorithms for Collaborative Filtering,” Proc. 14th Conf. Uncertainty in Artificial Intelligence, July 1998.
8. U. Shardanand and P. Maes, “Social Information Filtering: Algorithms for Automating ‘Word of Mouth’,” Proc. Conf. Human Factors in Computing Systems, 1995.

9. J. Delgado and N. Ishii, "Memory-Based Weighted-Majority Prediction for Recommender Systems," Proc. ACM SIGIR '99 Workshop Recommender Systems: Algorithms and Evaluation, 1999.
10. D. Billsus and M. Pazzani, "Learning Collaborative Information Filters," Proc. Int'l Conf. Machine Learning, 1998.
1. J.S. Breese, D. Heckerman, and C. Kadie, "Empirical Analysis of Predictive Algorithms for Collaborative Filtering," Proc. 14th Conf. Uncertainty in Artificial Intelligence, July 1998.
12. L. Getoor and M. Sahami, "Using Probabilistic Relational Models for Collaborative Filtering," Proc. Workshop Web Usage Analysis and User Profiling (WEBKDD '99), Aug. 1999.
13. K. Goldberg, T. Roeder, D. Gupta, and C. Perkins, "Eigentaste: A Constant Time Collaborative Filtering Algorithm," Information Retrieval J., vol. 4, no. 2, pp. 133-151, July 2001.

ПРИЛОЖЕНИЕ А

Кластеризация данных.




Рисунок А.1 — Демографическая кластеризация данных.

ПРИЛОЖЕНИЕ Б

Графический интерфейс приложения

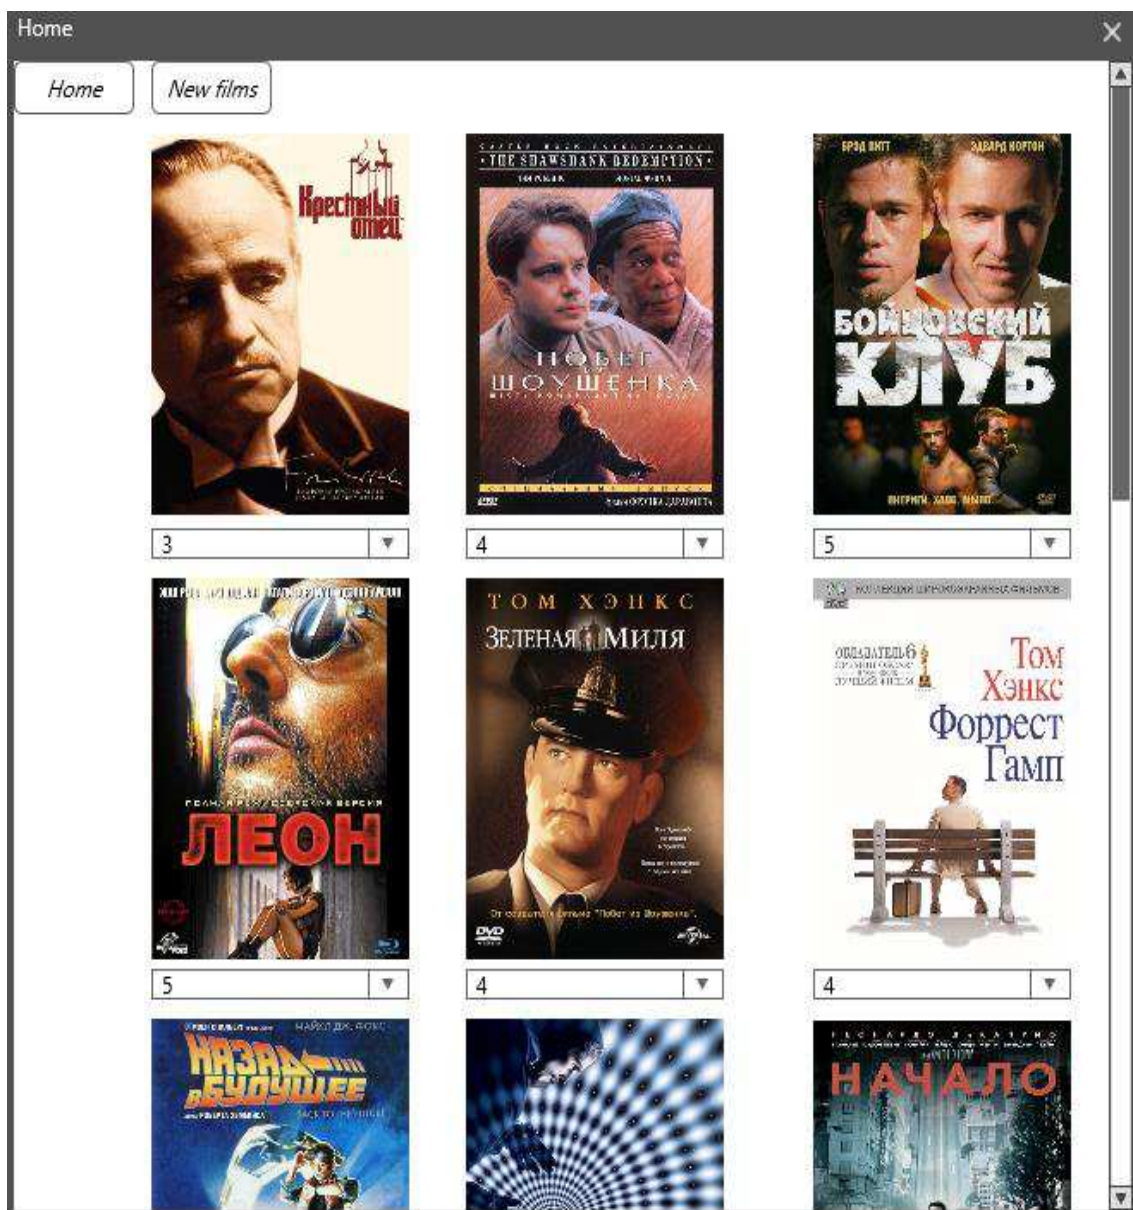


Рисунок Б.1 — Окно оценивания фильмов.

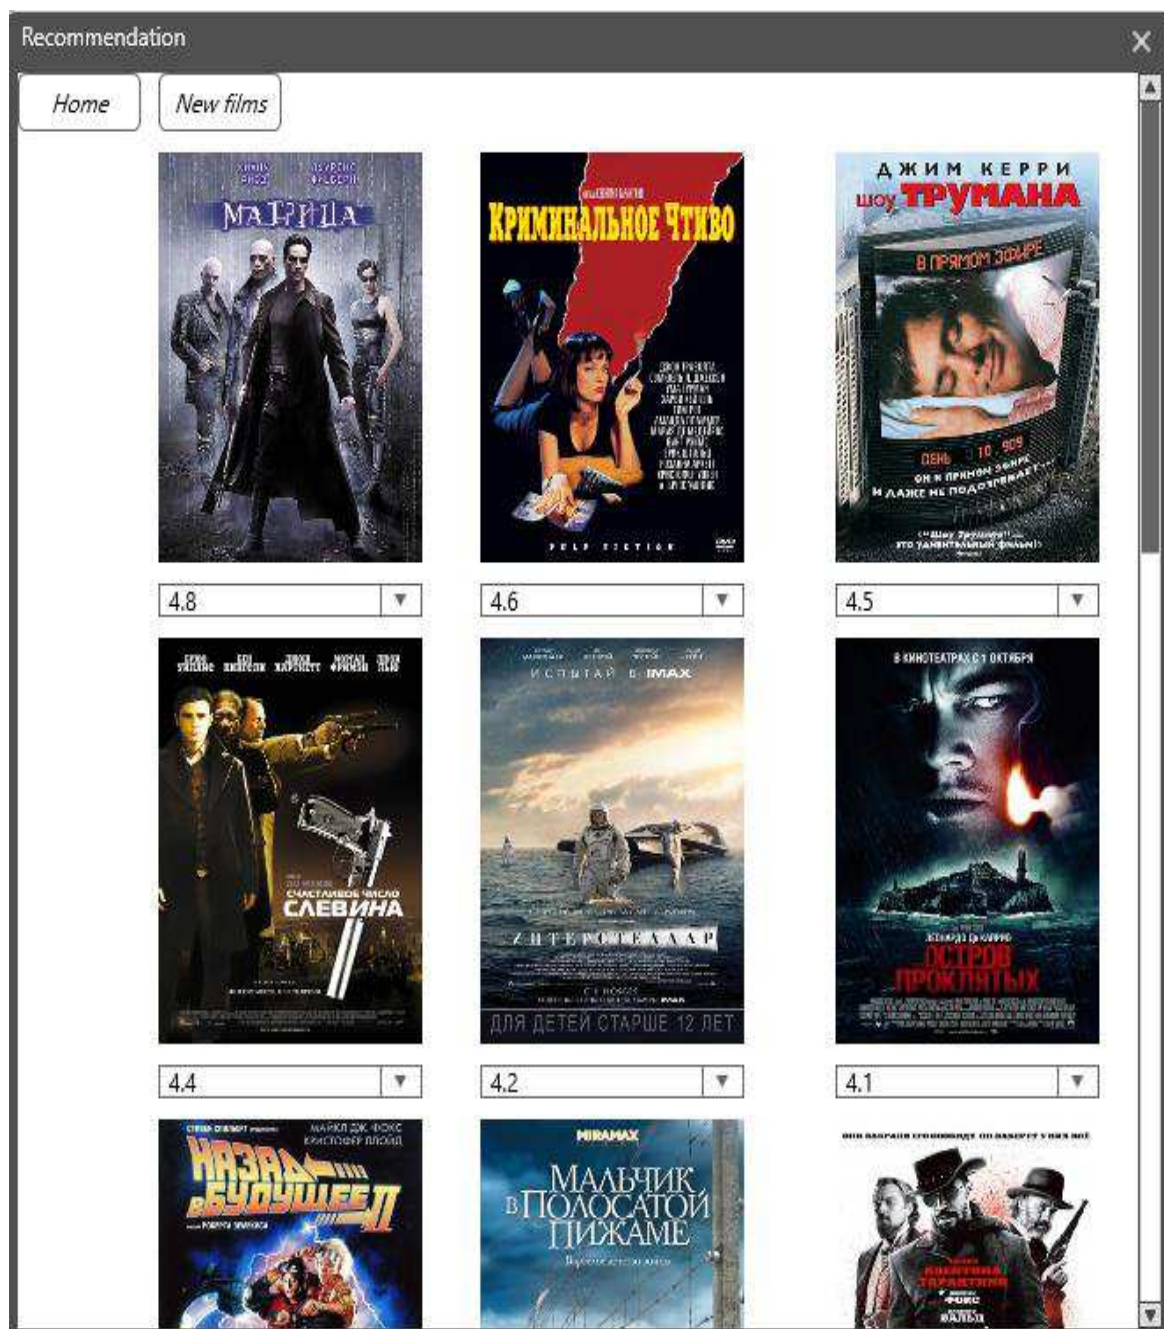
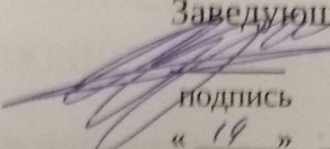


Рисунок Б.2 — Список рекомендованных фильмов.

Федеральное государственное автономное
образовательное учреждение
высшего образования
«СИБИРСКИЙ ФЕДЕРАЛЬНЫЙ УНИВЕРСИТЕТ»
Институт космических и информационных технологий
Кафедра информатики

УТВЕРЖДАЮ

Заведующий кафедрой

 А.С. Кузнецов

подпись

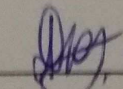
« 19 » 06 20 17 г.

БАКАЛАВРСКАЯ РАБОТА

27.03.03 — Системный анализ и управление

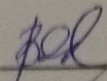
Формирование персонализированного предложения на основе личных
предпочтений клиента

Руководитель

 19.06.17 доцент, канд техн. наук
подпись, дата должность, ученая степень

А.А. Даничев

Выпускник

 19.06.17.
подпись, дата

Б.В. Вавулин

Красноярск 2017